

Alen Jugović\*  
Vlado Mezak\*\*  
Svjetlana Hess\*\*\*

UDK 656.615.012.122(497.5 Rijeka)  
Prethodno priopćenje  
Preliminary paper

## PRILOG ISTRAŽIVANJU PLANIRANJA LUČKIH KAPACITETA LUKE RIJEKA

### CONTRIBUTION TO RESEARCH OF PORT CAPACITY PLANNING AT THE PORT OF RIJEKA

#### ABSTRACT

*Seaports are complex systems integrating a number of business processes in which process insufficient and inadequate port capacities represent a problem resulting before all in non-competitive service and insufficient occupancy rate of these capacities. Efforts have been made to solve the problem of inadequate port capacities by updating and adjusting the port capacities to market demands while the problem of insufficient occupancy rate of these capacities remains unrecognized and no required attention has been paid to it within the port system. By applying the queue theory and setting up an appropriate model on the example of the Port of Rijeka, this paper tries to indicate the fact that the port capacities, in this case piers intended for reloading of general cargo, are waiting for incoming ships which are deficient and that it would be more economical to reduce capacities and to redevelop them for, e.g., accommodation of vessels intended for container working – respectively cargo reloading which is growing continuously. There is no need for the redevelopment to take a permanent course, but it should last at least as long as it is possible to engage unengaged capacities in percentage generating profit and no loss. The purpose of this research work is not to solve one specific problem within the port operations but to set up the methodology for individual issues that may appear and to show the solving of a specific case as illustration of the applied queue method in port operations.*

**JEL: D78, C44**

**Key words:** planning, port system, usability of port capacities, queue theory, port operations

#### 1. UVOD

U dosadašnjoj praksi i teoriji nisu dovoljno korištene mogućnosti primjene teorije redova čekanja u procesu planiranja lučkih kapaciteta. Razlog leži u činjenici da teorija redova čekanja zahtijeva interdisciplinarni pristup, tj. poznavanje ne samo kvantitativnih metoda nego i problematike na koju se odnosi razmatrani problem iz područja pomorstva.

U stručnoj i znanstvenoj literaturi predmet istraživanja (planiranje lučkih kapaciteta) ovog članka proučava se od sredine 70-ih godina prošloga stoljeća. Obradeni problemi morskih luka rješavali su se pomoću različitih modela, koristeći statističke metode, linearno programiranje, mješovito cjelobrojno programiranje, separabilno programiranje, razlomljeno programiranje, višekriterijalno programiranje, teoriju redova čekanja i druge kvantitativne

---

\* mr. sc., Pomorski fakultet Sveučilišta u Rijeci, Studentska 2, 51000 Rijeka, [ajugovic@pfri.hr](mailto:ajugovic@pfri.hr)

\*\* mr. sc., Lučka uprava Rijeka, Riva 1, 51000 Rijeka, [marketing.ri@portauthority.hr](mailto:marketing.ri@portauthority.hr)

\*\*\* dr. sc. Pomorski fakultet Sveučilišta u Rijeci, Studentska 2, 51000 Rijeka, [shess@pfri.hr](mailto:shess@pfri.hr)

Članak primljen u uredništvo: 25.09.2007.

metode. Od autora koji se bave problematikom prometnih djelatnosti lučkog sustava primjenom kvantitativnih metoda, izdvojeni su sljedeći istraživači: M. Noritake i S. Kimura, koji 1983. prikazuju metodu određivanja optimalnog broja pristana i metodu određivanja optimalnog kapaciteta pristana; autori A. A. Shabayek i W. W. Yeung su 2001., koristeći teoriju redova čekanja, postavili model rada kontejnerskog terminala.

Postoji znatan broj znanstvenih radova na polju teorije redova čekanja, primjerice za tip M/M/1 [2, 3, 7, 14]. Cullinane, Song i Wang [4] primjenjuju matematičko programiranje u ocjenjivanju produktivnosti kontejnerskih luka. Cullinane [5] istražuje moguće metode i njihovu primjenu za produktivnost i modeliranje efikasnosti luka i terminala. Whitt, Glynn i Melamed [11] primjenjuju procjenu dolazaka jedinica u sustav i koriste izjednačavanje vremenskih intervala u određivanju ponašanja stvarnih modela.

## 2. TEMELJNE ZNAČAJKE TEORIJE REDOVA ČEKANJA

Pod teorijom redova čekanja podrazumijeva se skup statističkih zakonitosti i teorema koji obrađuju različite probleme vezane uz čekanje nekih klijenata na neku uslugu. Kada jedinice koje treba uslužiti ili mjesta koja vrše tu uslugu “čekaju”, nastupaju problemi čekanja ili redovi čekanja. Ti problemi nastaju vrlo često u svakodnevnom životu, od čekanja ljudi u banci, dućanu i sl. do čekanja u transportu – u lukama brodovi, na aerodromu zrakoplovi, na parkiralištu i slično. Odgovarajuće rješenje tog problema može poboljšati kvalitetu življenja i povećati produktivnost. Iz navedenog se može zaključiti da redovi čekanja nastaju kada jedinice (ljudi, smetnje na strojevima, transportna sredstva itd.) dolaze u nekom vremenskom intervalu na mjesta usluge (blagajne, lučki ili drugi terminali i kapaciteti) u opsegu koji je privremeno ili stalno veći nego što je u tom vremenskom intervalu na raspolaganju kapacitet usluge. Kod uskih grla na uslužnom mjestu u određenom periodu nastaju prilazni redovi čekanja, dok u obrnutoj situaciji, kada su mjesta usluge slobodna te čekaju na jedinice koje će trebati uslužiti (lučki terminali čekaju brodove), nastaju redovi u odlasku. Iz navedenog se može zaključiti da problem teorije redova ima dualni karakter. U proučavanju operacija na mjestima usluge trebaju se naznačiti neke mjere kojima se promatrani sustav prati. Prva je mjera očekivana vrijednost koja pokazuje koliko će dugo neka jedinica čekati na uslugu. Druga mjera pokazuje postotak vremena kroz koje će uslužno mjesto biti nezaposleno. Dok prva mjera gleda na sustav s pozicije jedinice koja pristupa uslužnom mjestu, druga procjenjuje stupanj iskorištenosti uslužnog mjesta, a jedna i druga mjera koriste se za uravnoteženje razine usluge [1, 333. ].

U teoriji redova čekanja najvažniji elementi su jedinica – kupac i vršilac usluge – poslužitelj. Međusobno djelovanje jedinice i poslužitelja vezano je na vremenske intervale koji razdvajaju uzastopne dolaske jedinice – kupca i vrijeme potrebno da se obavi usluga po jedinici. Dolazak novih kupaca i vrijeme prikazuju se u obliku distribucije vjerojatnosti.

Način dolazaka i odlazaka jedinica glavni je predmet u analiziranju modela redova čekanja, ali i drugi čimbenici imaju značajnu ulogu u razvoju modela. Bitno je na koji način se odabiru jedinice iz reda čekanja za početak usluge, zatim koje su prihvatljive veličine redova, te imaju li izvori iz kojih dolaze jedinice konačan ili neograničeni broj jedinica.

Osnovni elementi modela redova čekanja ovise o [1, 335]:

- distribuciji dolazaka,
- distribuciji vremena usluge,
- planu usluživanja (serijski, paralelno, mreža),
- disciplini usluga (FCFS – prvi došao, prvi uslužen; LCFS – zadnji došao, prvi uslužen; SIRO – uslužen po slučajnom redoslijedu),
- duljini reda čekanja (konačan ili beskonačan),
- izvorima pozivanja i

- ljudskom ponašanju (varanje, zaobilaženje).

Poznavanje elemenata modela čekanja važno je iz dva razloga: da bi se utvrdio i shvatio teoretski model te da se prepozna realni model koji bi se mogao proučavati u nekom od teoretskih modela. Kada nekoliko jedinica može biti opsluženo istovremeno na više paralelnih uslužnih mjesta, kaže se da uslužni kapacitet ima više kanala. U lukama se može prepoznati slučaj jednog reda čekanja s više paralelnih kanala opsluživanja ako više brodova čeka red na više istovrsnih pristana, ili slučaj više redova čekanja s više paralelnih kanala opsluživanja ako više brodova čeka red na više raznovrsnih pristana.

Intenzitet toka dolazaka i intenzitet opsluživanja po kanalu su osnovne veličine koje određuju pojedini problem redova čekanja. Prva označava kapacitet izvora odakle pristižu jedinice u sustav, a druga kapacitet uslužnih mjesta. Njihov količnik je *pokazatelj iskorištenosti (opterećenja) uslužnog mjesta* ( $\rho$ ):  $\rho = \lambda / \mu$ .

Sustav će biti stabilan ako se vrijednost  $\rho$  kreće u intervalu od 0 do 1, odnosno ako je  $0 < \rho < 1$ . Ako je  $\rho \geq 1$ , dugoročno može doći do zagušenja sustava, jedinice će se nagomilavati tijekom vremena i sustav neće moći normalno funkcionirati. U tom slučaju treba se povećavati broj uslužnih mjesta (kanala) dok se ne postigne uvjet stabilnosti.

*Razdioba vremena dolazaka jedinica* – vrijeme između dva uzastopna dolaska jedinica u sustav opsluživanja može biti s jednakim intervalima, s nejednakim ali unaprijed određenim vremenskim intervalima i s nejednakim vremenskim intervalima dolazaka koji su slučajni, ali za koje je poznata njihova razdioba vjerojatnosti.

Realno je moguć neograničen broj različitih razdioba dolazaka, koje se najčešće klasificiraju na:

- pravilno distribuirane dolaske,
- potpuno slučajne dolaske (Poissonova i eksponencijalna razdioba dolazaka),
- dolaske distribuirane prema Erlangovoj razdiobi i
- općenito nezavisno distribuirane dolaske.

*Razdioba vremena opsluživanja* – vrijeme potrebno da jedno uslužno mjesto opsluži jednu jedinicu. Trajanje obavljanja usluge može biti determinističko ili može slijediti neku od teorijskih razdioba. Na temelju empirijskih podataka o vremenima obavljanja usluge, moguće je s hi-kvadrat testom odrediti koju razdiobu vjerojatnosti slijede empirijske podaci. Teorija redova čekanja ne može se primijeniti na slučajeve kada su intervali između sukcesivnih dolazaka i/ili vrijeme trajanja usluge slučajni i kada su nepoznate razdiobe vjerojatnosti.

Broj uslužnih mjesta u sustavu opsluživanja na kojima se istodobno mogu opsluživati korisnici (*broj kanala*) može biti unaprijed poznat, ili se na osnovi elemenata koji određuju proces čekanja određuje potreban broj uslužnih mjesta.

Maksimalni broj jedinica koje čekaju u redu i koje se upravo opslužuju (*kapacitet sustava opsluživanja*) pokazuju zauzetost sustava. Jedinica pristigla u potpuno zauzet sustav ne može stati u red čekanja, pa se zbog toga sustavi velikog kapaciteta obično prihvaćaju kao sustavi s beskonačnim kapacitetom.

*Luka* predstavlja sustav masovnog opsluživanja, koji prema svojim značajkama i svojstvima funkcioniranja čini određeni tip reda čekanja. Ulazne jedinice su brodovi koji formiraju red čekanja da bi bili opsluženi na nekom pristanu i nakon toga izašli iz sustava masovnog opsluživanja. Nakon što se utvrdi da se intenzitet dolazaka brodova i vrijeme njihova opsluživanja ponaša prema nekoj teorijskoj razdiobi mogu se koristiti formule koje je postavila teorija redova čekanja za izračunavanje pokazatelja funkcioniranja morske luke. U suprotnom se primjenjuju metode simulacije.

Metoda kojom se ispituje prema kojim se teorijskim razdiobama ponašaju intenzitet dolazaka brodova i vrijeme njihovog opsluživanja raspoređuju prema određenim teorijskim razdiobama zove se  $\chi^2$  – test i koristit će se za potrebe ovog rada.

Luku, s obzirom na problem redova čekanja, karakterizira nemogućnost predviđanja dolaska broda i vremena potrebnog za opsluživanje broda, a posljedica toga je neravnomjerno korištenje lučkih kapaciteta. Ako je broj brodova koji dolaze u luku veći od broja brodova koje postojeći kapaciteti mogu opslužiti, dolazi do čekanja brodova u redu, a ako je slučaj obrnut, tada brodovi ne čekaju, ali kapaciteti luke (pristana) nisu u potpunosti iskorišteni.

### **3. METODOLOGIJA ISTRAŽIVANJA ISKORISTIVOSTI KAPACITETA LUKE RIJEKA**

#### **3.1. Planiranje lučkih kapaciteta**

Planiranje kapaciteta u luci je vrlo složen zadatak jer je promet tereta neravnomjeren i oscilacije tog prometa uzrokuju problem dimenzioniranja kapaciteta. Da bi se pružila potpuna usluga, luka bi trebala raspolagati rezervnim kapacitetima za slučajeve maksimalnog prometa, no takvi kapaciteti bi bili neiskorišteni u drugim puno češćim situacijama kada ima manje prometa. Zato je lučke kapacitete potrebno planirati na način da ne dođe do zastoja u radu luke zbog prekobrojnih ili nedostatnih pristana, a sve u cilju rentabilnog poslovanja. Kapacitet luke je veličina kojom se izražava sposobnost luke da prihvati istovremeno određen broj brodova ili da u promatranoj vremenskoj jedinici prekrca određenu količinu tereta. Prekrcajne mogućnosti određene su brojem i kapacitetom prekrcajnih sredstava, a jedan od načina određivanja optimalnog kapaciteta je primjenom teorije redova čekanja.

Prilikom planiranja lučkih kapaciteta treba odgovoriti na sljedeća pitanja:

- 1) Koliki su raspoloživi kapaciteti, tj. koliki se opseg prometa može obaviti?
- 2) Koji i koliki su kapaciteti potrebni za ostvarenje planiranog prekrcaja?
- 3) Kako riješiti manjak, odnosno višak kapaciteta?

Neravnomjernost prometa je karakteristična za sve luke, a oscilacije koje se ne mogu izbjeći ni predvidjeti utječu na problem dimenzioniranja luke, posebno na planiranje broja pristana za brodove. Kada bi brodovi u luku dolazili redovito i kada bi vrijeme prekrcaja bilo uvijek isto, bilo bi jednostavno odrediti lučke kapacitete koji bi bili u potpunosti iskoristivi. Međutim, kako u praksi takvih slučajeva nema, potrebno je napraviti kompromis između dugog čekanja broda na slobodni pristan i niske zauzetosti pristana. Potrebno je riješiti problem čekanja, odnosno odrediti optimalan broj uslužnih mjesta (pristana) za koji će vrijeme čekanja ili troškovi prouzročeni čekanjem broda i pristana biti minimalni, s tim da se neće moći u potpunosti eliminirati čekanje, već će se gubici zbog čekanja svesti na minimum.

#### **3.2. Ispitivanje uvjeta primjene modela reda čekanja**

Utvrđivanje vrste razdiobe prema kojoj se ponašaju dolasci brodova i vrijeme opsluživanja vrši se pomoću statističkih testova kojima se odgovora na pitanje: prilagođavaju li se empirijske frekvencije nekoj teorijskoj razdiobi.

Na primjeru Luke Rijeka koristit će se  $\chi^2$  test za ispitivanje da li se empirijska razdioba dolazaka brodova i opsluživanja brodova na pristanima ponašaju po Poissonovoj razdiobi. Potom se može primjenom teorije redova čekanja dobiti odgovor na pitanje koliko je pristana potrebno imati na terminalu za generalni teret riječke luke.

U postupku ispitivanja slaganja empirijske razdiobe s teorijskom razdiobom postavlja se hipoteza:

- $H_0$  (nulta hipoteza): razdioba dolazaka brodova u luku ponaša se prema zakonitostima Poissonove razdiobe,
- $H_1$  (alternativna hipoteza): razdioba dolazaka brodova u luku ne ponaša se prema zakonitostima Poissonove razdiobe.

Nulta hipoteza moći će se prihvatiti ako rezultat  $\chi^2$  testa, odnosno vrijednost  $\chi^2$  izračunata za empirijsku razdiobu bude u intervalu  $[0, \chi_0^2]$ , pri čemu je  $\chi_0^2$  vrijednost iz statističkih tablica. Poželjna razina signifikantnosti je 5%, iako je prihvatljivo i da se vrijednosti slažu na razini 1% signifikantnosti, ali bolje je veća razina signifikantnosti. Broj stupnjeva slobode je druga važna veličina koja se mora uzeti u obzir prilikom postupka dokazivanja prilagodbi empirijskih s teorijskim razdiobama. Za Poissonovu razdiobu broj stupnjeva slobode je  $k = n - 2$ , pri čemu je  $n$  broj razreda ili grupa.

Da bi se dokazalo da se dolasci brodova i opsluživanje brodova ponašaju po Poissonovoj razdiobi potrebno je najprije odrediti ulazne parametre. Za Poissonovu razdiobu dolazaka brodova ulazni parametri su:

$n$  – broj razreda ili grupa,  $x_i$  – broj brodova u dolasku,  
 $f_i$  – broj dana,  $E_i$  – teorijske frekvencije.  
 $p(x_i)$  – vjerojatnost za  $x$ -tu vrijednost varijable pri Poissonovoj razdiobi,

Vjerojatnosti Poissonove razdiobe očitane su iz statističkih tablica.

Vrijednost  $\chi^2$  izračunava se po formuli:

$$\chi^2 = \sum_{i=1}^n \frac{(f_i - E_i)^2}{E_i}.$$

**Tablica 1.**

**Postupak izračunavanja  $\chi^2$**

$x_i$	$f_i$	$x_i f_i$	$p(x_i)$	$E_i = 365 \cdot p(x_i)$	$ f_i - E_i $	$\chi^2$
0	106	0	0,3012	110	4	0,145
1	134	134	0,3614	132	2	0,030
2	75	150	0,2169	79	4	0,202
3	37	111	0,0867	32	5	0,780
4	9	36	0,0260	12,2	0,8	0,050
5	2	10	0,0062			
6	2	12	0,0012			
	365	453		365,2		1,207

Izvor: Izradili autori

Dobivena vrijednost hi-kvadrat iznosi  $\chi^2 = 1,207$ ; broj stupnjeva slobode  $k = 3$ ; tablična vrijednost hi-kvadrata za 5% i 1% signifikantnosti je  $\chi_{0,05}^2 = 7,815$ ,  $\chi_{0,01}^2 = 11,341$ .

Na temelju prethodnih podataka može se donijeti zaključak da se prihvaća nulta hipoteza budući da je vrijednost izračunatog hi-kvadrata manja od tablične i za 5% i za 1% signifikantnosti. Prema tome, razdioba dolazaka brodova na terminalu za generalni teret u riječkoj luci ponaša se prema zakonitostima Poissonove razdiobe. Analogan postupak provodi se i za ispitivanje slaganja razdiobe intenziteta opsluživanja te je dobiveno da razdioba intenziteta opsluživanja brodova također slijedi Poissonovu razdiobu.

Nakon što je hi-kvadrat testom dokazano da se empirijske razdiobe toka dolazaka brodova i opsluživanja brodova ponašaju po Poissonovoj teorijskoj razdiobi, može se nastaviti s određivanjem optimalnog broja pristana na terminalu za generalni teret riječke luke teorijom redova čekanja, primjenjujući softverski program WinQSB.

### 3.3. Postavljanje modela reda čekanja

Prema klasifikaciji problema redova čekanja terminal za generalni teret riječke luke je sustav s čekanjem koji dozvoljava beskonačni broj brodova u redu čekanja, a dokazano je da se razdioba dolazaka brodova i razdioba opsluživanja raspoređuju prema Poissonovoj razdioba. Prema tome pokazatelji funkcioniranja terminala za generalni teret riječke luke izračunavaju se prema formulama za sustav čekanja s oznakom  $M/M/S/\infty$ , gdje je  $S = 12$  jer terminal raspolaže sa 12 pristana (kanala za opsluživanje). Kada brod za generalni terete dođe u luku, može se vezati na bilo koji od pristana za generalni teret.

Da bi se donijela odluka o broju pristana, treba odrediti neke kriterije za odlučivanje. U primjeru terminala za generalni teret riječke luke kao kriterij će se uzeti postotak iskorištenja pristana, prosječan broj brodova koji čekaju, vrijeme provedeno u redu čekanja, kao i vjerojatnost čekanja broda. Hipoteza koju se izračunom treba potvrditi je da se u riječkoj luci koristi preveliki broj pristana na terminalu za generalni teret, a ti neiskorišteni pristani utječu na neefikasnost poslovanja, s obzirom da njihovo zadržavanje u lučkom sustavu nije rentabilno ako se ne koriste. Uzeti su podaci za 2005. godinu kada je promet iznosio 870 163 t (odnosno 453 broda). U tabeli 1 prikazan je broj brodova po mjesecima pristiglih na terminal za generalni teret riječke luke s 12 pristana u 2005. godini.

**Tablica 2.**

**Dolazak brodova na terminalu za generalni teret u 2005. god. po mjesecima**

Mjesec	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	Ukupno
Broj brodova	31	44	37	39	42	47	40	28	40	35	31	39	453

Izvor: Lučka uprava Rijeka

Da bi se prikazao problem reda čekanja potrebno je odrediti broj jedinica koje pristižu u sustav. Ako zbog slučajnih dolazaka broj jedinica nije isti u istim intervalima, uzima se prosječan broj jedinica u jedinici vremena – *intenzitet toka dolazaka brodova* ( $\lambda$ ). Iz tablice 2 vidljivo je da je u promatranoj 2005. godini na terminal za generalni teret u riječkoj luci došlo 453 brodova. Kad se taj broj podijeli sa brojem dana u godini dobit će se intenzitet toka dolazaka brodova po danu.

$$\lambda = 453 : 365 = 1,24$$

Kapacitet uslužnog mjesta (pristan) izražava se brojem jedinica (brodova, količina tereta) koje se mogu opslužiti u jedinici vremena – *intenzitet opsluživanja po pristanu* ( $\mu$ ). Ako je prosječan broj brodova (količina tereta) koji traži uslugu veći od kapaciteta pristana, postojeći kapaciteti ne mogu zadovoljiti zahtjeve pa su brodovi primorani čekati na sidrištu za uslugu prekrcaja. Obrnuto, ako je prosječan broj brodova manji od kapaciteta pristana, odmah će biti opsluženi, ali budući da su kapaciteti predimenzionirani, pojavit će se “čekanje” pristana koji neće biti u potpunosti iskorišteni. Intenzitet opsluživanja po pristanu izračunava se kombiniranjem podataka o odnosima tereta u riječkoj luci s normama prekrcaja. U riječkoj luci odnos teškog i lakog generalnog tereta je 80% prema 20%, odnosno od svakih 1000 tona generalnog tereta, 800 tona su teški koleti, pri čemu se u jednoj smjeni, jednom dizalicom može prekrcati 600 tona teškog, odnosno samo 160 tona lakog tereta. Ako se ti podaci stave u odnos dobije se: <sup>1</sup>

$$800 : 600 = 1,33$$

$$200 : 160 = 1,25$$

$$1,33 + 1,25 = 2,58$$

iz čega slijedi da jedna dizalica u riječkoj luci prosječno po jednoj smjeni može prekrcati :

$$1000 : 2,58 = 387,6 \text{ tona generalnog tereta.}$$

U riječkoj luci je na terminalu za generalni teret u 2005. godini pristalo 453 brodova i prekrano je 870 163 tone tereta, odnosno po brodu je prosječno prekrano 1 920,9 tona. Ako se zna da je na terminalu 12 pristana, a na svakom pristanu su u prosjeku dvije obalne dizalice koje prosječno prekravaju 387,6 tona tereta po smjeni i da se na dan radi dvije smjene, također uzimajući u obzir koeficijent neravnomjernosti dolazaka brodova (0,7), tada proizlazi:  $387,6 \times 2 \text{ smjene} \times 2 \text{ dizalice} \times 0,7 = 1085,28 \text{ tone/dan}$ , tj. da se na jednom pristanu može na dan prekrcati prosječno 1085,28 tone.

Stavi li se u odnos mogućnost prekrcaja na jednom pristanu i prosječna veličina broda u tonama prekranog tereta:  $1085,28 : 1920,9 = 0,565 \text{ brod/dan}$ , tj. dobije se vrijednost koja pokazuje koliko se, ako se poštuju norme prekrcaja, može u prosjeku opslužiti brodova u jednom danu na jednom mjestu opsluživanja, odnosno dobije se intenzitet opsluživanja po kanalu -  $\mu = 0,565 \text{ brod/dan}$ .

Osnovni cilj pri istraživanju sustava opsluživanja pomoću teorije redova je odrediti kvantitativne pokazatelje rada promatranog procesa opsluživanja i utvrditi minimalan broj uslužnih mjesta s kojima se može ostvariti tražena kvaliteta opsluživanja.

Da bi se odredio optimalan broj pristana na terminalu za generalni teret riječke luke, korišten je softverski program WinQSB, uz čiju pomoć su se dobila različita rješenja, uvrštavanjem vrijednosti za:

- intenzitet toka dolazaka brodova ( $\lambda$ ): 1,24
- intenzitet opsluživanja brodova ( $\mu$ ): 0,565
- broj pristana: od 3 do 12.

Za broj pristana  $S = 12$ , dobiveni su sljedeći rezultati:

#### System Performance Summary for luka

	Performance Measure	Result
1	System: M/M/12 From Formula	
2	Customer arrival rate (lambda) per day =	1,2400
3	Service rate per server (mu) per day =	0,5650
4	Overall system effective arrival rate per day =	1,2400
5	Overall system effective service rate per day =	1,2400
6	Overall system utilization =	18,2891 %
7	Average number of customers in the system (L) =	2,1947
8	Average number of customers in the queue (Lq) =	0,0000
9	Average number of customers in the queue for a busy system (Lb) =	0,2238
10	Average time customer spends in the system (W) =	1,7699 days
11	Average time customer spends in the queue (Wq) =	0,0000 days
12	Average time customer spends in the queue for a busy system (Wb) =	0,1805 days
13	The probability that all servers are idle (Po) =	11,1393 %
14	The probability an arriving customer waits (Pw) or system is busy (Pb) =	0,0004 %

Analogno su dobiveni i ostali pokazatelji (za broj pristana od 3 do 11), a prikazani su u tablici 3.

**Tablica 3.****Rezultati dobiveni računalnim programom WinQSB za primjer terminala za generalni teret riječke luke**

parametri br.pristana S	$\rho_s$	$L_q$	$W_q$	$P_w$
3	0,7316	1,4702	1,1856	0,5395
4	0,5487	0,2739	0,2209	0,2253
5	0,4389	0,0651	0,0525	0,8322
6	0,3658	0,0157	0,0126	0,2719
7	0,3135	0,0036	0,0029	0,0789
8	0,2743	0,0008	0,0006	0,0205
9	0,2438	0,0002	0,0001	0,0048
10	0,2195	0,0000	0,0000	0,0010
11	0,1995	0,0000	0,0000	0,0002
12	0,1829	0,0000	0,0000	0,0000

Izvor: Izradili autori

**3.4. Ocjena rezultata i osvrt na buduće poslovanje**

Iz tabele 2, prema postojećem stanju od 12 pristana, može se zaključiti sljedeće:

- koeficijent iskorištenja lučkog sustava  $\rho = 0,1829$  ukazuje da je sustav opterećen 18%, što upućuje na nedovoljnu iskorištenost kapaciteta;
- prosječan broj brodova u redu čekanja  $L_q = 0$  kao i prosječno vrijeme broda u redu čekanja  $W_q = 0$  dana ukazuje na potpuno zanemarivo čekanje broda u sustavu, odnosno može se reći da brod uopće ne čeka, nego da ga se odmah opsluži po dolasku u sustav, a što je vidljivo i iz vrijednosti  $P_w = 0$  što predstavlja vjerojatnost da će brod morati čekati na uslugu ukrcaja/iskrcaja.

Iz dobivenih rezultata jasno je vidljivo da je istraživani sustav neprikladan i da su potrebne promjene, tj. potrebno je smanjiti broj kanala (pristana) u cilju efikasnijeg funkcioniranja sustava.

Stoga su i izračunate vrijednosti za manji broj pristana od 12, koliko ih ima na terminalu i pratiti dobivene vrijednosti te pokušati odrediti optimalan broj pristana potrebnih za kvalitetno opsluživanje brodova i efikasno poslovanje luke.

Iz tablice 3 može se zaključiti da sa 4 pristana na terminalu za generalni teret riječka luka može efikasno poslovati i pri tome imati opterećenje sustava od 55%, prosječno 0,27 brodova koji čekaju na uslugu u prosjeku 0,22 dana odnosno 5,3 sati, a vjerojatnost da će brod koji dođe morati čekati iznosila bi 0,22.

Koliko se tereta može očekivati u riječkoj luci u sljedećem 15-godišnjem razdoblju teško je i nezahvalno procjenjivati. Na temelju podataka za promet od 2000. do 2005. godine (tablica 4) dobivene su jednadžbe linearnog i paraboličnog trenda na temelju kojih je izrađena procjena za 2010., 2015. i 2020. godinu.



**Tablica 4.****Promet generalnog tereta riječke luke u razdoblju od 2000. do 2005. godine**

Godina	2000.	2001.	2002.	2003.	2004.	2005.
Promet (t)	702.546	727.000	654.480	746.970	839.700	870.163

Izvor: Lučka uprava Rijeka

Rezultati su dobiveni s pomoću računalnog programa STATISTICA 7 i prikazani u tablici 5.

**Tablica 5.****Rezultati prognoze količine generalnog tereta u riječkoj luci**

Prognoza	2010.	2015.	2020.
Linearni trend	1.119.289	1.300.528	1.481.767
Parabolični trend	1.686.808	3.102.057	5.134.312

Izvor: Izradili autori

U odnosu na prekranih 702 546 tone u 2000. godini, prognoza za 2020. godinu je 111% više tereta, odnosno veća je 2,1 puta. Predviđanja se odnose samo na količinu prekranog tereta, a ne i na broj brodova, pa se u nedostatku podataka koriste dostupne vrijednosti. Može se uzeti da je prosječna količina tereta prekrana po jednom brodu konstantna veličina i da su norme prekrcaja također konstante. U tom slučaju u predviđeno mjesto za vrijednosti  $\lambda$  pri izračunu za 2020. godinu uvrstit će se:

$$1.481.767 \text{ t/god.} : 1.920,9 \text{ t/brod} = 771,4 = \text{cca } 771 \text{ brod/god.}$$

$$\lambda = 771 : 365 = 2,11$$

Vrijednost  $\mu$  se ne mijenja i ostaje 0,565.

Ako se želi trajnije riješiti problem čekanja u riječkoj luci, tada se prema izrađenoj prognozi za intenzitet toka dolazaka  $\lambda$  treba uvrstiti vrijednost 2,11. Tablica 5 prikazuje tražene vrijednosti u ovisnosti o broju kanala, a pri intenzitetu opsluživanja  $\mu = 0,565$ .

**Tablica 6.**

**Funkcioniranje lučkog sustava u ovisnosti od broja kanala opsluživanja**

parametri br.pristana S	$\rho_s$	$L_q$	$W_q$	$P_w$
4	0,9339	12,0540	5,7128	0,8570
5	0,7469	1,3467	0,6382	0,4563
6	0,6224	0,3694	0,1751	0,2241
7	0,5335	0,1156	0,0548	0,1011
8	0,4668	0,0366	0,0174	0,0418
9	0,4149	0,0113	0,0053	0,0159
10	0,3734	0,0033	0,0016	0,0055
11	0,3395	0,0009	0,0004	0,0018
12	0,3112	0,0002	0,0001	0,0005

Izvor: Izradili autori

Iz tablice 6 može se zaključiti da će 2020. godine, kada se predviđa da će se na terminalu za generalni teret prekrcavati godišnje 1 481 767 tona, riječka luka moći efikasno poslovati sa 7 pristana i pri tome imati opterećenje pristana od 53%, prosječno 0,12 brodova koji će čekati na uslugu u prosjeku 0,05 dana, odnosno 1,2 sati, a vjerojatnost da će brod koji dođe morati čekati iznosila bi 10,1%.

#### **4. ZAKLJUČAK**

Uz pomoć teorije redova čekanja i njezinom primjenom na lučko poslovanje omogućava se efikasnije planiranje lučkih kapaciteta, kako današnjih tako i onih budućih.

Pošto se teorija redova čekanja, kao analitička metoda može primijeniti jedino ukoliko se matematički dokaže da se empirijske distribucije dolazaka i opsluživanja brodova ponašaju po nekoj teorijskoj razdiobi, prije same primjene teorije redova, hi-kvadrat testom dokazano je da se empirijske distribucije u riječkoj luci ponašaju prema Poissonovoj razdiobi.

Riječka luka je primjer luke u kojoj se ne posluje efikasno. Na terminalu za generalni teret egzistira 12 pristana i primjenom teorije redova čekanja u ovom radu dokazana je hipoteza da je to neprimjeren broj za sadašnje, a i za buduće procijenjene tokove tereta.

Zaključuje se da čak i za 20 godina riječka luka može efikasno poslovati s manjim brojem pristana nego što ih danas koristi. Broj pristana privremeno bi se trebao smanjiti na 4, tijekom vremena po potrebi povećavati, a u međuvremenu Lučka uprava i poduzeće Luka koje je dobilo koncesiju za te prostore trebali bi pronaći primjerenija rješenja korištenja suvišnih pristana.

#### **LITERATURA**

- Barković, D., (2001.), Operacijska istraživanja, Ekonomski fakultet Osijek, Osijek.
- Bose, S. J., (2002.), An Introduction to Queuing Systems-Chapter 1, Kluwer/Plenum Publishers, London.
- Camm, J. D., Evans, J. R., (1996.), Management Science: Modeling, Analysis and Interpretation, South-Western College Publishing, Cincinnati.
- Cullinane, K., Song, D. W., Wang, T., (2005.), The Application of Mathematical Programming Approaches to Estimating Container Port Production Efficiency,

- Journal of Productivity Analysis, Springer Netherlands. 24 (1): 73-92.
- Cullinane, K., (2003.), The Productivity and Efficiency of Ports and Terminals: Methods and Applications - The Handbook of Maritime Economics and Business, LLP, London.
- Ivković, Z., (1970.), Uvod u teoriju verovatnoće, slučajne procese i matematičku statistiku, Građevinska knjiga, Beograd.
- Lawrence, J. A., Pasternack, B. A., (1998.), Applied Management Science, a Computer-Integrated Approach for Decision Making, John Wiley and Sons, New York.
- Lazić, M., (1981.), Primena metoda teorije masovnog opsluživanja u analizi vremena zadržavanja brodova u luci Koper, Saobraćaj, 28 (3): 493-499.
- Tijms, H. C., (1994.), Stochastic Models an Algorithmic Approach, John Wiley and Sons, New York.
- Wentzel, E., Ovcharov, L., (1986.), Applied Problems in Probability Theory, Mir Publishers, London.
- Whitt, W., Glynn, P. W., Melamed, B., Estimating Customer and Time Averages, Operations Research, Vol. 41, No. 2, 1993, pp. 400-408
- Zenzerović, Z., (2003.), Teorija redova čekanja - Stohastički procesi II dio, Pomorski fakultet u Rijeci, Rijeka.
- <http://staff.um.edu.mt/jskl1/simweb/mm1.htm>

## **PRIOLOG ISTRAŽIVANJU PLANIRANJA LUČKIH KAPACITETA LUKE RIJEKA**

### **SAŽETAK**

*Morske luke su složeni sustavi u kojima su integrirani brojni poslovni procesi, pri čemu nedostatni i neodgovarajući lučki kapaciteti predstavljaju problem koji se prvenstveno očituje u nekonkurentnoj usluzi i nedovoljnoj popunjenosti tih kapaciteta. Problem neodgovarajućih lučkih kapaciteta nastoji se riješiti modernizacijom i prilagodbom lučkih kapaciteta potrebama tržišta, dok problem nedovoljne popunjenosti tih kapaciteta ostaje neprepoznat i njemu se u lučkom sustavu ne daje potrebna pozornost. U ovom znanstvenom radu primjenom teorije redova čekanja i postavljanjem odgovarajućeg modela na primjeru riječke luke ukazat će se na činjenicu da lučki kapaciteti, u ovom primjeru pristani namijenjeni pretovaru generalnog tereta, čekaju na dolazak brodova kojih ima nedostavno i da bi racionalnije bilo reducirati kapacitete i izvršiti prenamjenu u npr. kapacitete za prihvrat brodova namijenjenih prekrcaju kontejnera – odnosno tereta koji kontinuirano raste. Prenamjena ne mora biti trajna, ali barem do trenutka kada će biti moguće nezaposlene kapacitete ponovno zaposliti u postotku koji donosi dobit, a ne gubitke. Cilj ovog znanstvenog rada nije u tome da se riješi jedan konkretni problem u lučkom poslovanju, već da se postavi metodologija za pojedinu vrstu problema koji se može pojaviti te da rješavanje konkretnog primjera ilustrira primjenu metode redova čekanja na lučko poslovanje.*

**JEL: D78, C44**

**Ključne riječi:** planiranje, lučki sustav, iskoristivost lučkih kapaciteta, teorija redova čekanja, lučko poslovanje